加微信：642945106 发送“ 赠送 ”领取赠送精品课程
发数字“ 2 ”获取众筹列表

10 | Java编译器（二）：语法分析之后，还要做些什么？

2020-06-24 宫文学

编译原理实战课 进入课程 >

讲述：宫文学
时长 18:16 大小 16.74M

你好，我是宫文学。

上一讲，我带你了解了 Java 语言编译器的词法分析和语法分析功能，这两项工作是每个编译器都必须要完成的。那么，根据第 1 讲我对编译过程的介绍，接下来就应该是语义分析和生成 IR 了。对于 javac 编译器来说，生成 IR，也就是字节码以后，编译器就完成任务了。也就是说，javac 编译器基本上都是在实现一些前端的功能。

不过，由于 Java 的语法特性很丰富，所以即使只是前端，它的编译功能也不少。那么，除了引用消解和类型检查这两项基础工作之外，你是否知道注解是在什么时候处理的呢？[illegible]型呢？还有各种语法糖呢？

所以，今天这一讲，我就带你把 Java 编译器的总体编译过程了解一遍。然后，我会把重点放在语义分析中的引用消解、符号表的建立和注解的处理上。当你学完以后，你就能真正理解以下这些问题了：

符号表是教科书上提到的一种数据结构，但它在 Java 编译器里是如何实现的？编译器如何建立符号表？

引用消解会涉及到作用域，那么作用域在 Java 编译器里又是怎么实现的？

在编译期是如何通过注解的方式生成新程序的？

为了方便你理解 Java 编译器内部的一些对象结构，我画了一些类图（如果你不习惯看类图的话，可以参考下面的图表说明，比如我用方框表示一个类，用小圆圈表示一个接口，几种线条分别代表继承关系、引用关系和接口实现）。

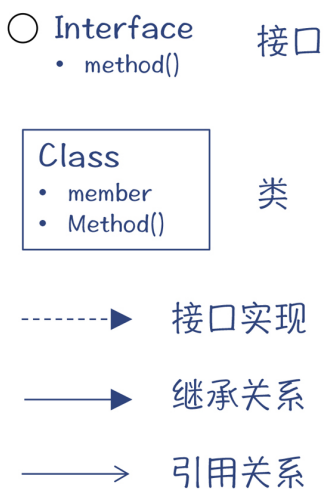

图 1：课程中用到的类图的图表说明

在课程开始之前，我想提醒几点：建议你在一个良好的学习环境进入今天的学习，因为你需要一步步地，仔细地跟住我的脚步，避免在探索过程中迷路；除此之外，你的手边还需要一个电脑，这样随时可以查看我在文章中提到的源代码。

了解整个编译过程

现在，你可以打开 jdk.compiler 模块中的 **com.sun.tools.javac.comp 包**对应的源代码目录。

comp 应该是 Compile 的缩写。这里面有一个 com.sun.tools.javac.comp.CompileStates 类，它的意思是编译状态。其中有一个枚举类型 CompileState，里面列出了所有的编译阶段。

你会看到，词法和语法分析只占了一个环节（PARSE），生成字节码占了一个环节，而剩下的 8 个环节都可以看作是语义分析工作（建立符号表、处理注解、属性计算、数据流分析、泛型处理、模式匹配处理、Lambda 处理和去除其他语法糖）。

复制代码

```
public enum CompileState {
    INIT(0),           //初始化
    PARSE(1),          //词法和语法分析
    ENTER(2),          //建立符号表
    PROCESS(3),        //处理注解
    ATTR(4),           //属性计算
    FLOW(5),           //数据流分析
    TRANSTYPES(6),     //去除语法糖：泛型处理
    TRANSPATTERNS(7), //去除语法糖：模式匹配处理
    UNLAMBDA(8),       //去除语法糖：LAMBDA处理(转换成方法)
    LOWER(9),          //去除语法糖：内部类、foreach循环、断言等。
    GENERATE(10);      //生成字节码
    ...
}
```

防止倒卖请务必加
首发微信：1716143665

另外，你还可以打开 **com.sun.tools.javac.main.JavaCompiler** 的代码，看看它的 **compile() 方法**。去掉一些细节，你会发现这样的代码主干，从中能看出编译处理的步骤：

复制代码

```
processAnnotations(                                  //3：处理注解
  enterTrees(stopIfError(CompileState.PARSE,         //2：建立符号表
    initModules(stopIfError(CompileState.PARSE,
      parseFiles(sourceFileObjects))                 //1：词法和语法分析
    ))
  ),classnames);

...
case SIMPLE:
  generate(                                          //10：生成字节码
    desugar(                                         //6~9：去除语法糖
      flow(                                          //5：数据流分析
        attribute(todo))));                          //4：属性计算
```

其中，PARSE 阶段的成果就是生成一个 AST，后续的语义分析阶段会基于它做进一步的处理：

enterTrees()：对应 ENTER，这个阶段的主要工作是建立符号表。

processAnnotations()：对应 PROCESS 阶段，它的工作是处理注解。

attribute()：对应 ATTR 阶段，这个阶段是做属性计算，我会在下一讲中给你做详细的介绍。

flow()：对应 FLOW 阶段，主要是做数据流分析。我在第 7 讲中就提到过数据流分析，那时候是用它来做代码优化。那么，难道在前端也需要做数据流分析吗？它会起到什么作用？这些问题的答案我也会在下一讲中为你揭晓。

desugar()：去除语法糖，其实这里包括了 TRANSTYPES（处理泛型）、TRANSPATTERNS（处理模式匹配）、UNLAMBDA（处理 Lambda）和 LOWER（处理其他所有的语法糖，比如内部类、foreach 循环等）四个阶段，我会在第 12 讲给你介绍。

generate()：生成字节码，对应了 GENERATE 阶段，这部分内容我也会在第 12 讲详细介绍。

在今天这一讲，我会给你介绍前两个阶段的工作：建立符号表和处理注解。

首先，我们来看看 Enter 阶段，也就是建立符号表的过程。

ENTER 阶段：建立符号表

Enter 阶段的主要代码在 **com.sun.tools.javac.comp.Enter 类**中。在这个阶段，会把程序中的各种符号加到符号表中。

建立符号表

在第 5 讲中，我已经介绍了符号表的概念。符号表是一种数据结构，它保存了程序中所有的定义信息，也就是你定义的每个标识符，不管是变量、类型，还是方法、参数，在符号表里都有一个条目。

那么，我们再深入看一下，什么是符号。

其实，符号代表了一门语言的基础构成元素。在 java.compiler 模块中定义了 Java 语言的构成元素（Element），包括模块、包、类型、可执行元素、变量元素等。这其中的每个元素，都是一种符号。

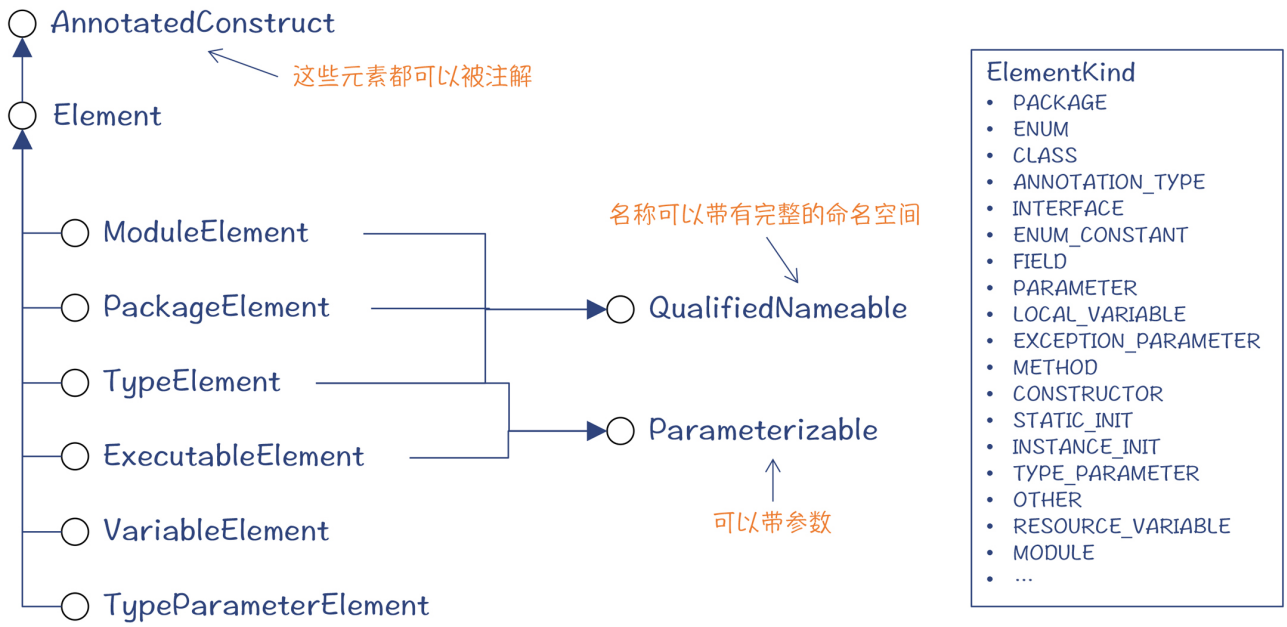

图 2：Java 语言的基本构成元素

而在 jdk.compiler 模块中，定义了这些元素的具体实现，也就是 Symbol，符号。

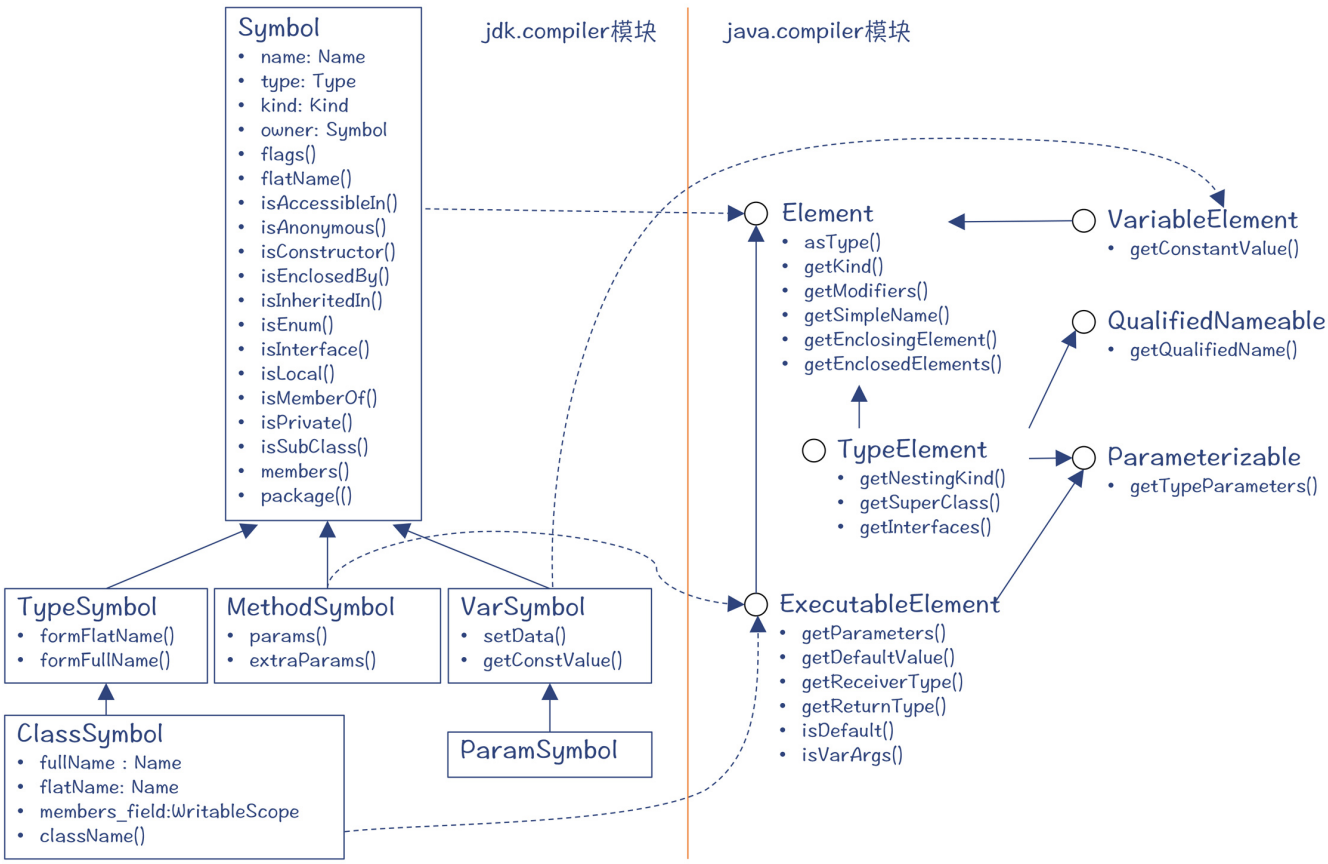

图 3：Symbol 及其子类

符号里记录了一些重要的属性信息，比如名称（name）、类型（type）、分类（kind）、所有者（owner）等，还有一些标记位，标志该符号是否是接口、是否是本地的、是否是私有的，等等，这些信息在语义分析和后续编译阶段都会使用。另外，不同的符号还有一些不同的属性信息，比如变量符号，会记录其常数值（constValue），这在常数折叠优化时会用到。

那么，Enter 过程是怎样发生的呢？你可以看一下 com.sun.tools.javac.comp.MemberEnter 类中的 **visitVarDef() 方法**。

实际上，当看到一个方法使用 visit 开头的时候，你应该马上意识到，这个方法是被用于一个 Visitor 模式的调用中。也就是说，Enter 过程是一个对 AST 的遍历过程，遍历的时候，会依次调用相应的 visit 方法。visitVarDef() 是用于处理变量声明的。

我们还以 MyClass 的编译为例来探索一下。MyClass 有一个成员变量 a，在 Enter 阶段，编译器就会为 a 建立符号。

我们来看看它的创建过程：

复制代码

```
public class MyClass {
    public int a = 2+3;
    public int foo(){
        int b = a + 10;
        return b;
    }
}
```

我从 visitVarDef() 中挑出了最重要的三行代码，需要你着重关注。

复制代码

```
...
//创建Symbol
VarSymbol v = new VarSymbol(0, tree.name, vartype, enclScope.owner);
...
tree.sym = v;        //关联到AST节点
...
```

```
7  enclScope.enter(v); //添加到Scope中
8
```

第一行，是**创建 Symbol**。

第二行，是**把 Symbol 关联到对应的 AST 节点**（这里是变量声明的节点 JCVaraibleDecl）。

你可以看一下各个 AST 节点的定义，其中的类、方法、变量声明、编译单元，以及标识符，都带有一个 sym 成员变量，用来关联到一个符号。这样后续在遍历树的时候，你就很容易查到这个节点对应的 Symbol 了。

不过你要注意，**各种声明节点（类声明、方法声明等）对应的符号，是符号的定义。而标识符对应的 Symbol，是对符号的引用。**找到每个标识符对应的定义，就是语义分析中的一项重要工作：引用消解。不过，引用消解不是在 Enter 阶段完成的，而是在 ATTR 阶段。

你在跟踪编译器运行的时候，可以在 JCClassDecl 等 **AST 节点的 sym 变量上**打个中断标记，这样你就会知道 sym 是什么时候被赋值的，从而也就了解了整个调用栈，这样会比较省事。

延伸一句：当你调试一个大的系统时，选择好恰当的断点很重要，会让你事半功倍。

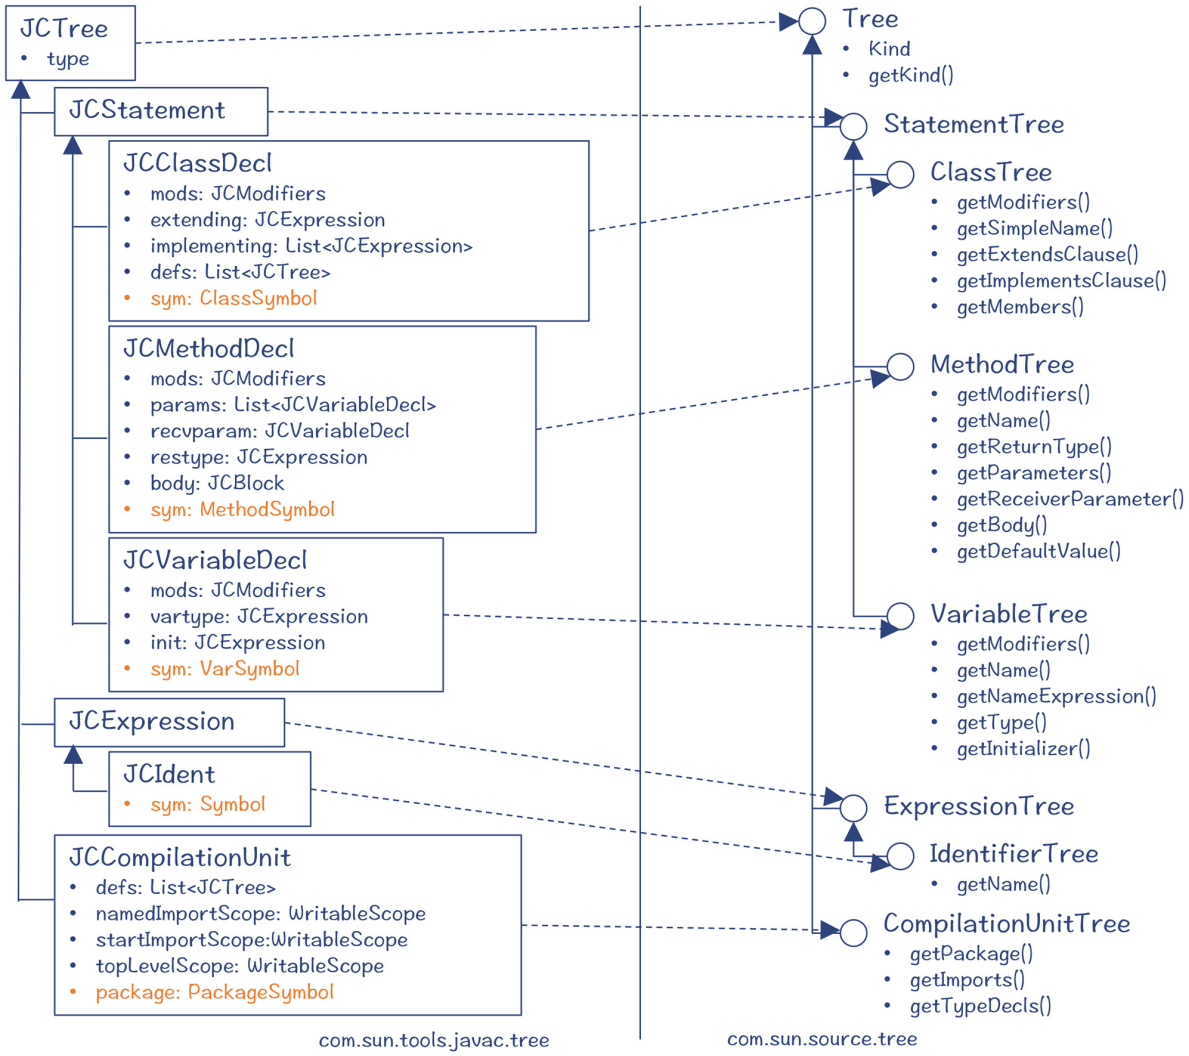

图 4：一些重要的 AST 节点的属性和方法，其中多个 AST 节点中都有对 Symbol 的引用

最后来看一下第三行代码，这行代码是**把 Symbol 添加到 Scope 中**。

什么是 Scope？Scope 就是作用域。也就是说，在 Enter 过程中，作用域也被识别了出来，每个符号都是保存在相应的作用域中的。

在第 4 讲，我们曾经说过，符号表可以采用与作用域同构的带层次的表格。Java 编译器就是这么实现的。符号被直接保存进了它所在的词法作用域。

在具体实现上，Java 的作用域所涉及的类比较多，我给你整理了一个类图，你可以参考一下：

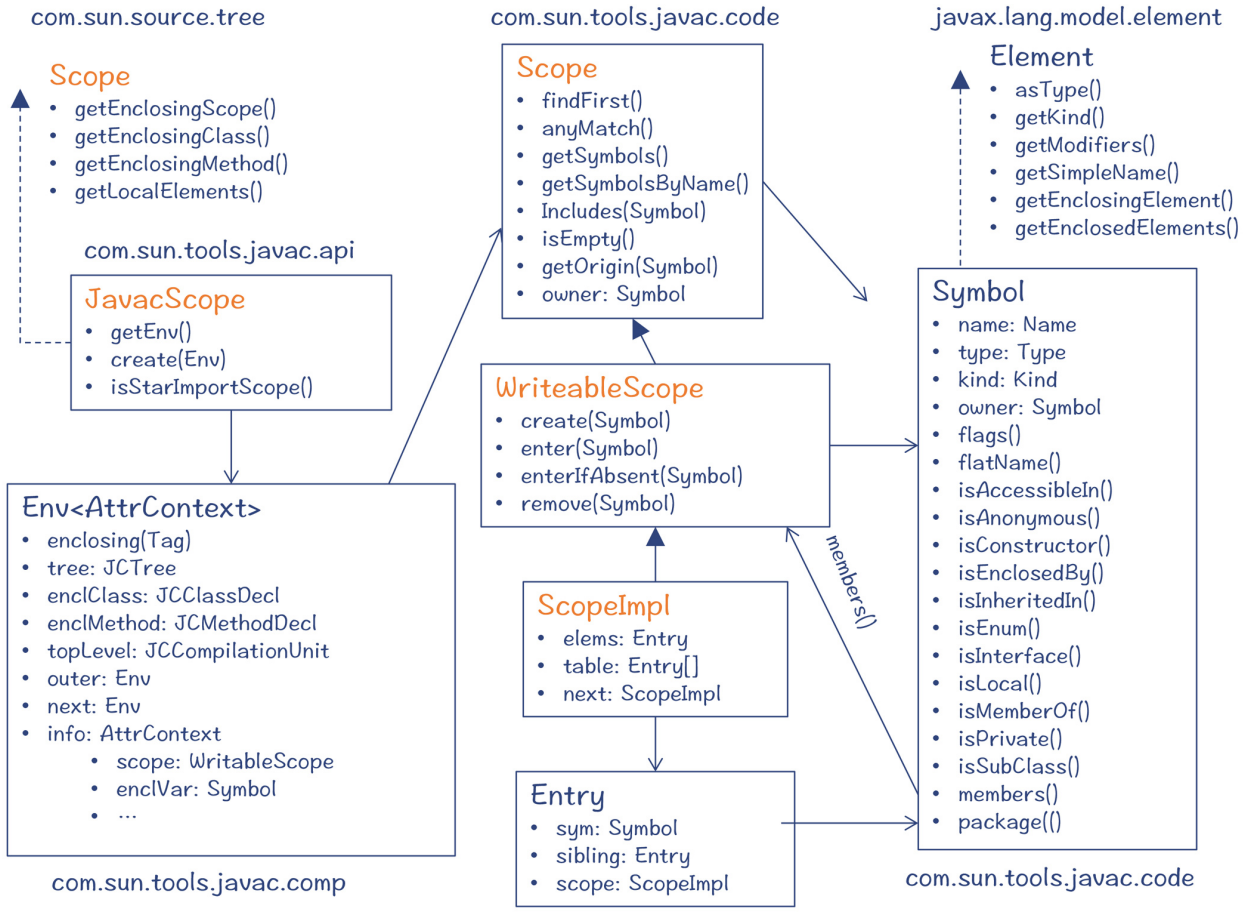

图 5：与 Scope 有关的类

其中有几个关键的类和接口，需要给你介绍一下。

首先是 **com.sun.tools.javac.code.Scope$ScopeImpl** 类：这是真正用来存放 Symbol 的容器类。通过 next 属性来指向上一级作用域，形成嵌套的树状结构。

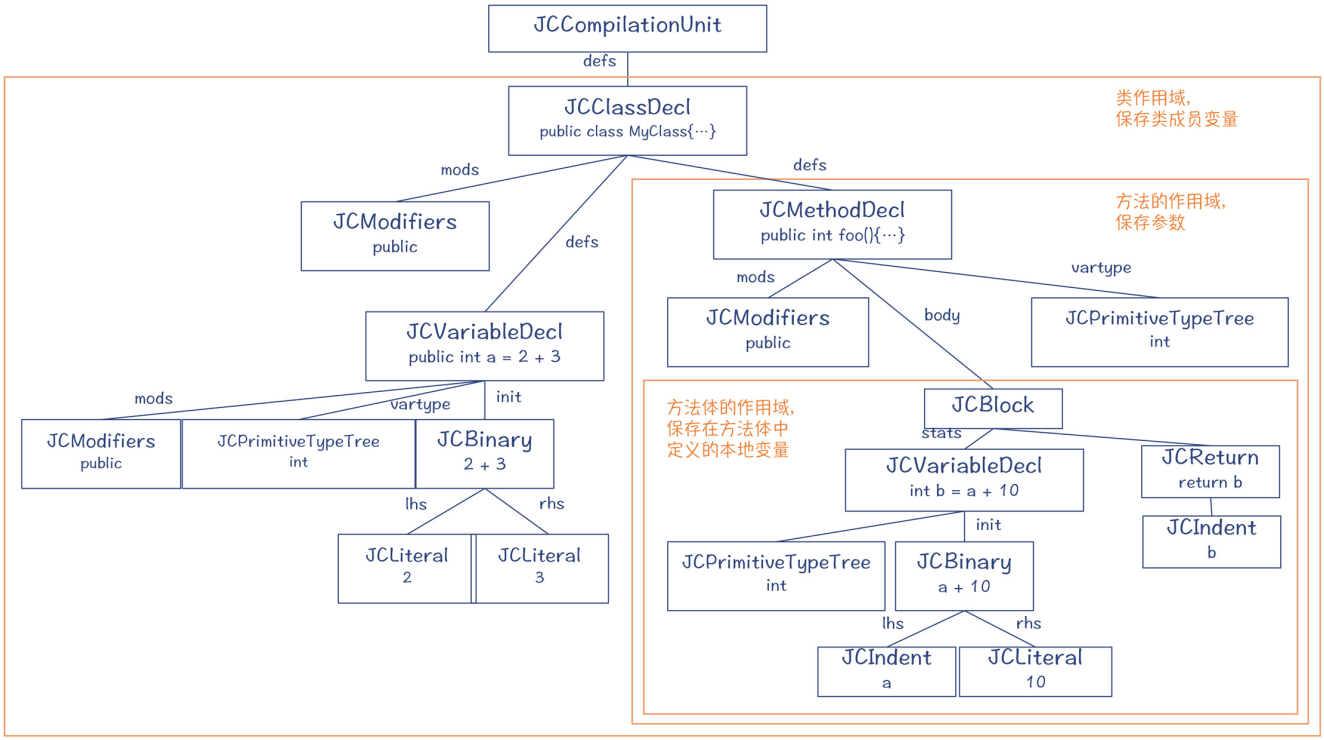

图 6：AST 中的作用域

但是，在处理 AST 时，如何找到当前的作用域呢？这就需要一个辅助类：**Env<AttrContext>**。Env 的意思是环境，用来保存编译过程中的一些上下文信息，其中就有当前节点所处的作用域（Env.info.scope）。下图展示的是在编译过程中，所使用的 Env 的情况，这些 Env 也构成了一个树状结构。

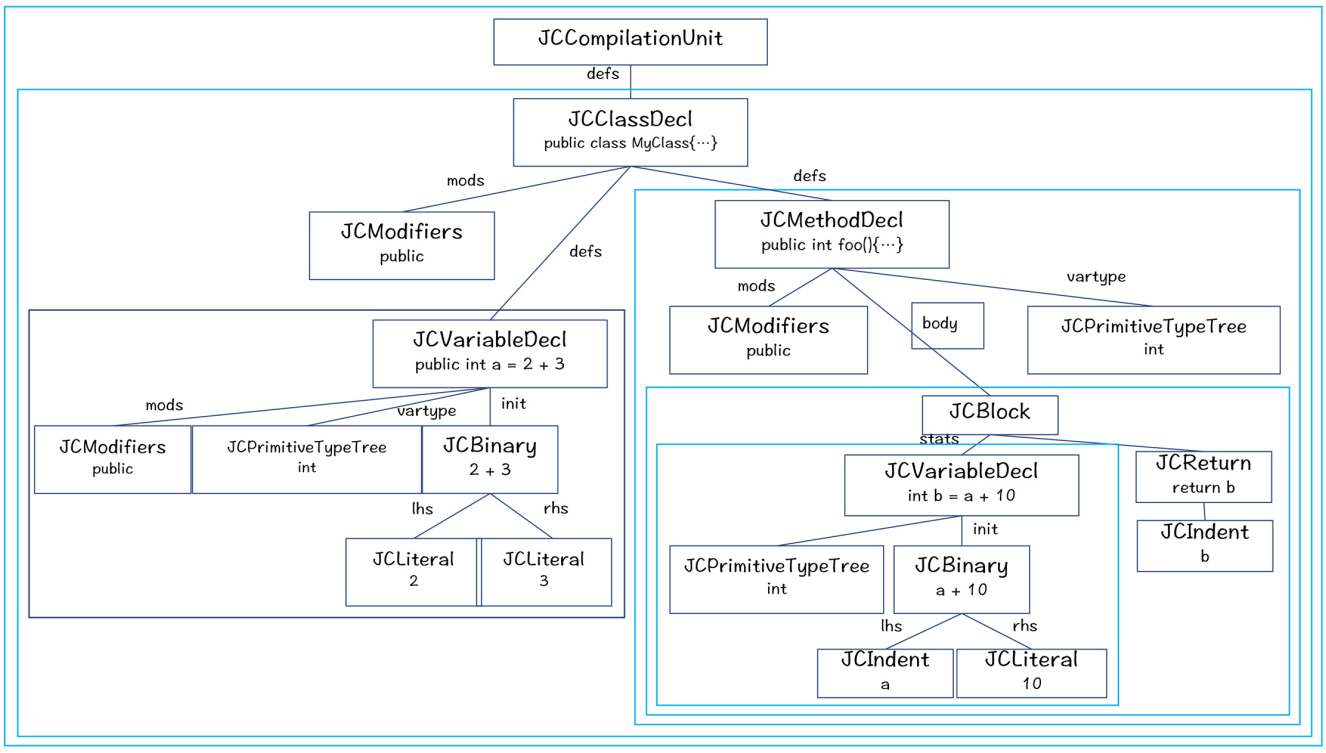

图 7：Env< AttrContext> 构成的树状结构

然后是 **com.sun.source.tree.Scope 接口：**这是对作用域的一个抽象，可以获取当前作用域中的元素、上一级作用域、上一级方法以及上一级类。

好了，这就是与符号表有关的数据结构，后续的很多处理工作都要借助这个数据结构。比如，你可以思考一下，如何基于作用域来做引用消解？在下一讲，我会给你揭晓这个问题的答案。

两阶段的处理过程

前面讨论的是符号表的数据结构，以及建立符号表的大致过程。接下来，我们继续深究一下建立符号表算法的一个重要特点：**Enter 过程是分两个阶段完成的。**

你可以打开 Enter 类，看看 Enter 类的头注释，里面对这两个阶段做了说明。

1. 第一个阶段：只是扫描所有的类（包括内部类），建立类的符号，并添加到作用域中。但是每个类定义的细节并没有确定，包括类所实现的接口、它的父类，以及所使用的类型参数。类的内部细节也没有去扫描，包括其成员变量、方法，以及方法的内部实现。
2. 第二个阶段：确定一个类所缺失的所有细节信息，并加入到符号表中。

这两个阶段，第一个阶段做整个程序的扫描，把所有的类都识别出来。而第二个阶段是在需要的时候才进行处理的。

这里的问题是：**为什么需要两个阶段？只用一个阶段不可以吗？**

我借一个例子给你解释一下原因。你看看下面这段示例代码，在 Enter 过程中，编译器遍历了 MyClass1 的 AST 节点（JCClassDecl），并建立了一个 ClassSymbol。但在遍历到它的成员变量 a 的时候，会发现它不认识 a 的类型 MyClass2，因为 MyClass2 的声明是在后面的。

复制代码

```
public class MyClass1{
   MyClass2 a;
}
class MyClass2{
```

```
5 }
```

怎么办呢？我们只好分成两个阶段去完成扫描。在第一个阶段，我们为 MyClass1 和 MyClass2 都建立符号，并且都放到符号表中；第二阶段，我们再去进一步扫描 MyClass1 的内部成员的时候，就能为成员变量 a 标注正确的类型，也就是 MyClass2。

我在第 4 讲中说过，语义分析的特点是上下文相关的。通过对比，你会发现，处理上下文相关情况和上下文无关情况的算法，它们是不一样的。

语法解析算法处理的是上下文无关的情况，因此无论自顶向下还是自底向上，整个算法其实是线性执行的，它会不断地消化掉 Token，最后产生 AST。对于上下文相关的情况，算法就要复杂一些。对 AST 各个节点的处理，会出现相互依赖的情况，并且经常会出现环形依赖，因为两个类互相引用在 Java 语言里是很常见的。加上这些依赖关系以后，AST 就变成了一张图。

而语义分析算法，实质上就是对图的遍历算法。我们知道，图的遍历算法的复杂度是比较高的。编译器一般要采用一定的**启发式（Heuristic）**的算法，人为地找出代价较低的遍历方式。Java 编译器里也采用了启发式的算法，我们尽量把对图的遍历简化为对树的遍历，这样工作起来就会简单得多。

对 AST 的遍历采用了 Visitor 模式。下图中我列出了一些采用 Visitor 模式对 AST 进行处理的程序。Enter 程序是其中的一个。

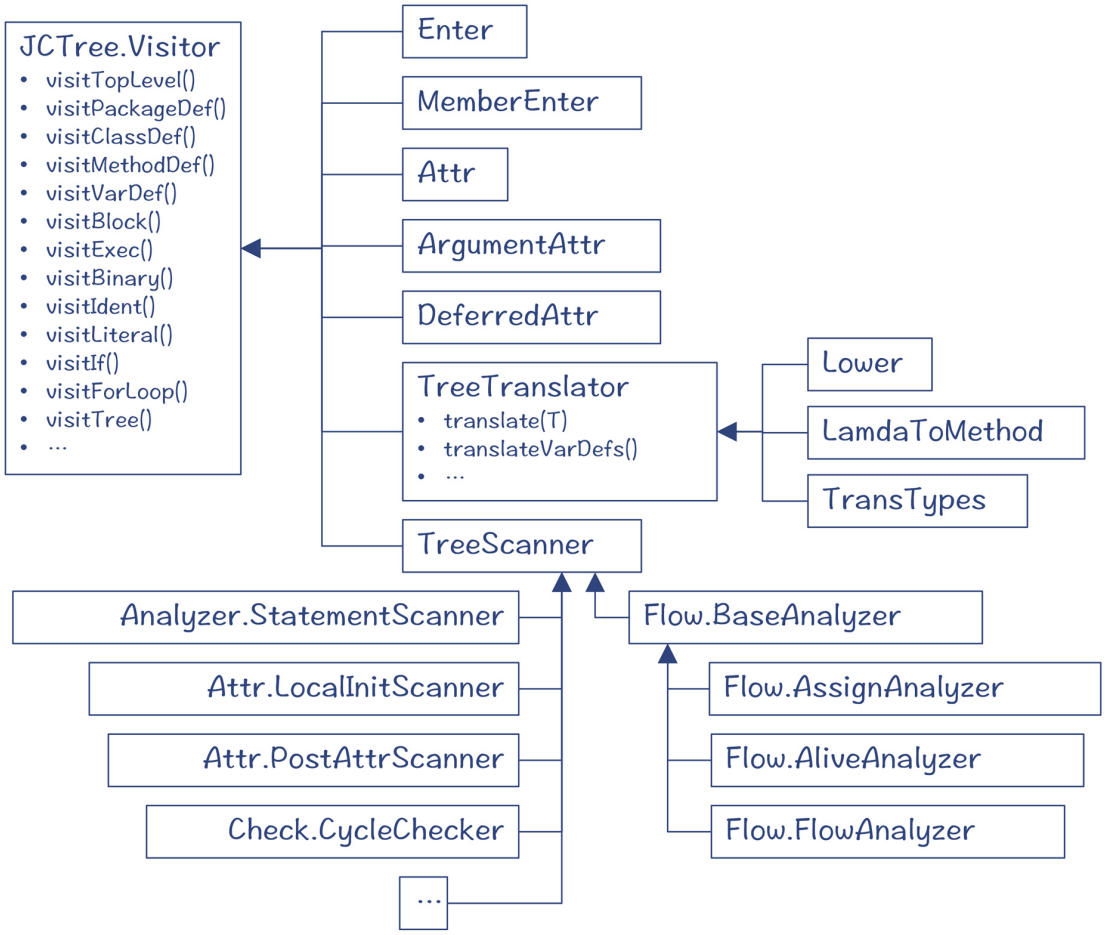

图 8：对 AST 进行处理的 Visitor 模式的部分程序

所以，语义分析就是由各种对 AST 进行遍历的算法构成的。在跟踪 Java 编译器执行的过程中，你还会发现多个处理阶段之间经常发生交错。比如，对于方法体中声明的局部变量，它的符号不是在 ENTER 阶段创建的，而是在 ATTR 阶段又回过头来调用了与建立符号表有关的方法。你可以先想想这又是什么道理。这里留下一个伏笔，我会在下一讲中给你解答。

系统符号表

前面说的符号表，保存了用户编写的程序中的符号。可是，还有一些符号，是系统级的，可以在不同的程序之间共享，比如原始数据类型、java.lang.Object 和 java.lang.String 等基础对象、缺省的模块名称、顶层的包名称等。

Java 编译器在 Symtab 类中保存这些系统级的符号。系统符号表在编译的早期就被初始化好，并用于后面的编译过程中。

以上就是 ENTER 阶段的所有内容。接着，编译器就会进入下一个阶段：PROCESS 阶段，也就是处理注解。

PROCESS 阶段：处理注解

注解是 Java 语言中的一个重要特性，它是 Java 元编程能力的一个重要组成部分。所谓元编程，简单地说，就是用程序生成或修改程序的能力。

Java 的注解需要在编译期被解析出来。在 Java 编译器中，注解被看作是符号的元数据，所以你可以看一下 SymbolMetadata 类，它记录了附加在某个符号上的各种注解信息。

然后呢，编译器可以在三个时机使用这些注解：一是在编译时，二是在类加载时，三是在类运行时。

对于后两者，编译器需要做的工作比较简单，把注解内容解析出来，放到 class 文件中。这样的话，PROCESS 阶段不需要做什么额外的工作。

而有些注解是要在编译期就处理的，这些注解最后就没必要保存到 class 文件。因为它们的使命在编译阶段就完成了。

那在编译阶段会利用注解做什么呢？最主要的用法，是根据注解动态生成程序，并且也被编译器编译。在后面探索 Java 的 JIT 编译器时，你会看到采用这种思路来生成程序的实例。你可以用简单的注解，就让注解处理程序生成很长的、充满“刻板代码”的程序。

我写了一个非常简单的示例程序，来测试 Java 编译器处理注解的功能。该注解叫做 HelloWorld：

```
@Retention(RetentionPolicy.SOURCE)   //注解用于编译期处理
@Target(ElementType.TYPE)            //注解是针对类型的
public @interface HelloWorld {
}
```

针对这个注解，需要写一个注解处理程序。当编译器在处理该注解的时候，就会调用相应的注解处理程序。你可以看一下 HelloWorldProcessor.java 程序。它里面的主要逻辑是获取被注解的类的名称，比如说叫 Foo，然后生成一个 HelloFoo.java 的程序。这个程序里有一个 sayHello() 方法，能够打印出“Hello Foo”。如果被注解的类是 Bar，那就生成一个 HelloBar.java，并且打印“Hello Bar”。

我们看一下 Foo 的代码。你注意，这里面有一个很有意思的现象：在 Foo 里调用了 HelloFoo，但 HelloFoo 其实当前并没有生成！

复制代码

```
@HelloWorld
public class Foo {
    //HelloFoo类是处理完注解后才生成的。
    static HelloFoo helloFoo = new HelloFoo();
    public static void main(String args[]){
        helloFoo.sayHello();
    }
}
```

你可以在命令行编译这三个程序。其中编译 Foo 的时候，要用 -processor 选项指定所采用的注解处理器。

复制代码

```
javac HelloWorld.java
javac HelloWorldProcessor.java
javac -processor HelloWorldProcessor Foo.java
```

在这个编译过程中，你会发现当前目录下生成了 HelloFoo.java 文件，并且在编译 Foo.java 之前就被编译了，这样在 Foo 里才能调用 HelloFoo 的方法。

你可以在 IDE 里跟踪一下编译器对注解的处理过程。借此，你也可以注意一下编译器是如何管理编译顺序的，因为 HelloFoo 一定要在 Foo 之前被编译。

扩展：Debug 对注解的处理过程需要有一定的技巧，请参考我为你整理的配置指南。

你会发现，在 Enter 之后，声明 helloFoo 这个成员变量的语句的 vartype 节点的类型是 ErrorType，证明这个时候编译器是没有找到 HelloFoo 的定义的。

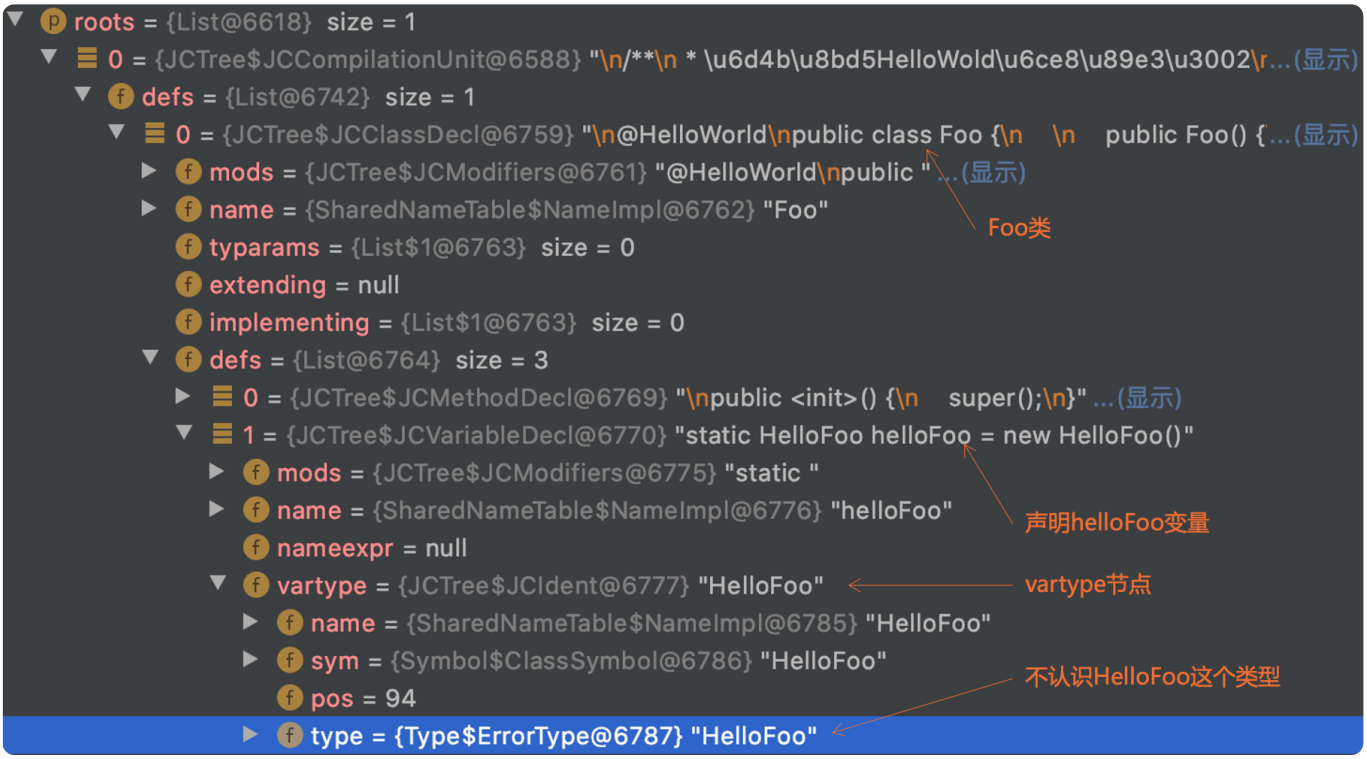

图 9：在处理注解之前，还没有生成 HelloFoo

不过，在编译器处理完毕注解以后，HelloFoo 就会被生成，Foo 类的 ENTER 过程还会重走一遍，这个时候相关类型信息就正确了。

课程小结

好了，本讲我们首先对 Java 的编译过程做了一个顶层的介绍，然后分析了 ENTER 和 PROCESS 阶段所做的工作。希望你能有以下收获：

1. 对前端编译过程可以有更加细致的了解，特别是对语义分析阶段，会划分成多个小阶段。由于语法分析的本质是对图做处理，所以实际执行过程不是简单地逐个阶段顺序执行，而是经常交织在一起，特别是 ENTER 阶段和 ATTR 阶段经常互相交错。
2. ENTER 阶段建立了符号表这样一个重要的数据结构。我们现在知道 Java 的符号表是按照作用域的结构建立的，而 AST 的每个节点都会对应某个作用域。
3. PROCESSOR 阶段完成了对注解的处理。你可以在代码里引用将要生成的类，做完注解处理后，这些类会被生成并编译，从而使得原来的程序能够找到正确的符号，不会报编译错误。

在最后，为了帮你将今天的内容做一个梳理，我提供一张思维导图，供你参考，整理知识：

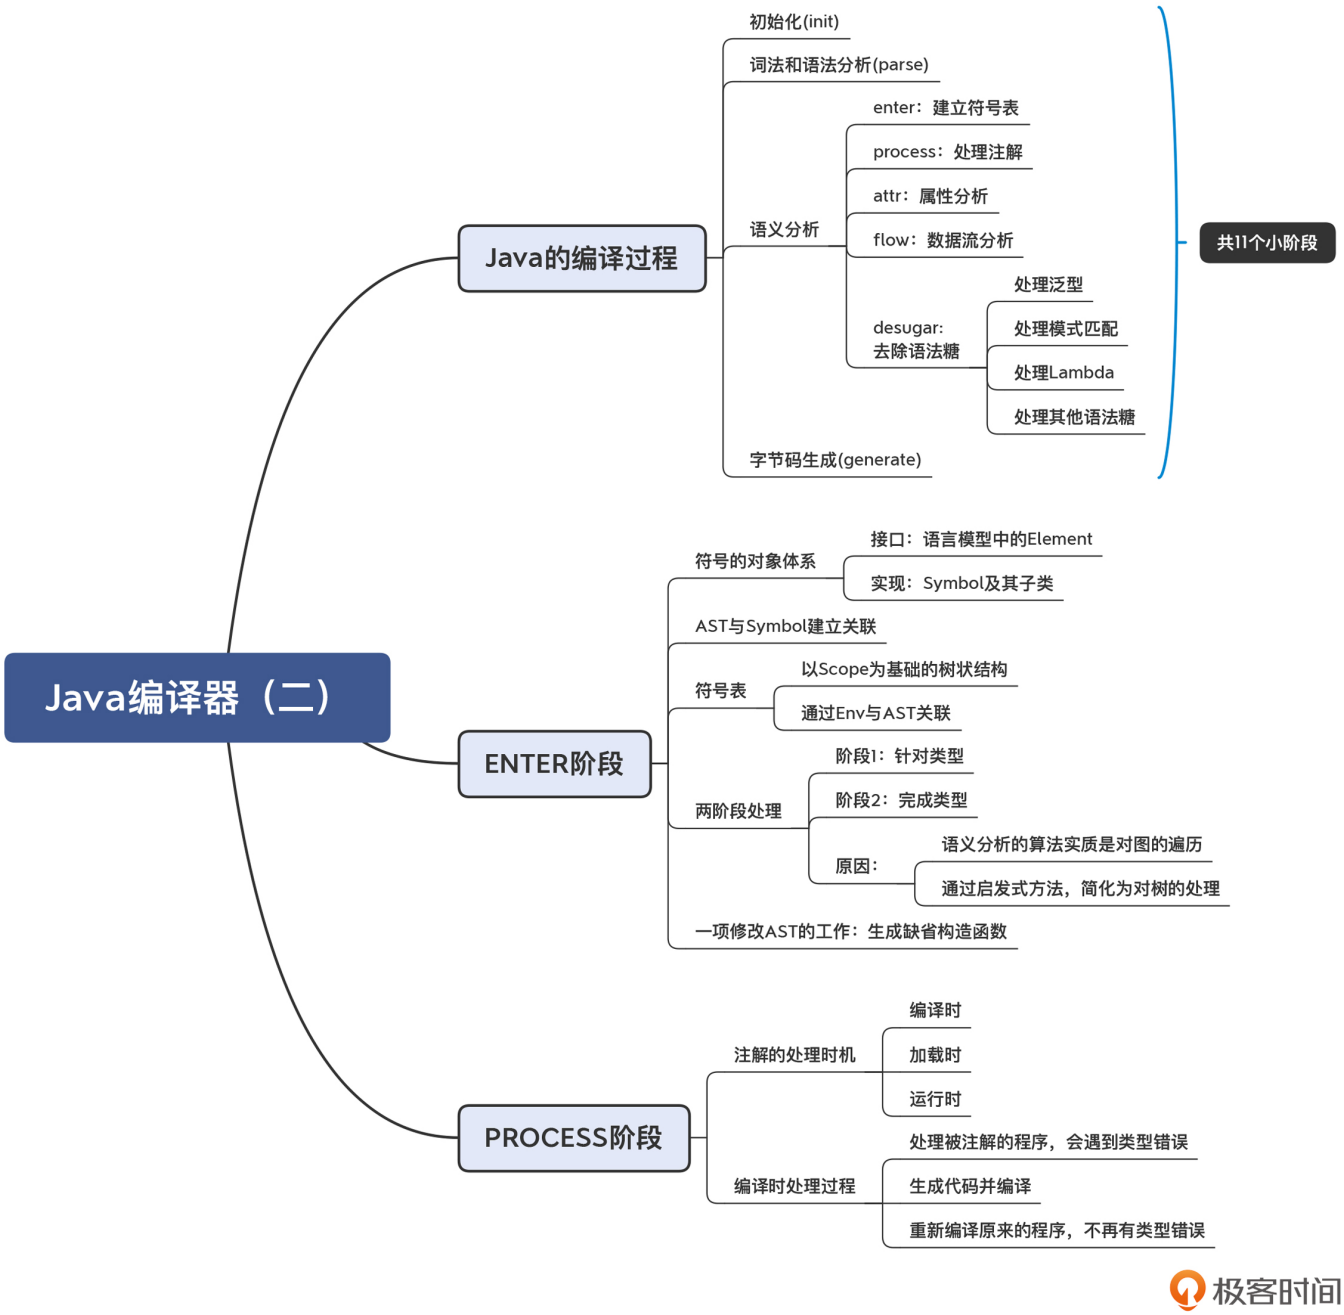

一课一思

在 Java 语言中，对于下面的示例代码，会产生几个作用域，你觉得它们分别是什么？

复制代码

```
public class ScopeTest{
    public int foo(int a){
        if(a>0){
          //一些代码
        }
        else{
          //另一些代码
        }
    }
}
```

欢迎在留言区分享你的答案，如果觉得有收获，也欢迎你把今天的内容分享给更多的朋友。

参考资料

关于注解的官方教程，你可以参考这个链接。

扩展知识

Java 编译器的功能很多。如果你有精力，还可以探索一些有趣的细节功能，比如：你知道 Java 在编译阶段，会自动生成缺省的构造函数吗？

ENTER 的第二个阶段任务是由 TypeEnter 类来完成的，你可以查看一下这个类的说明。它内部划分成了 4 个小的阶段，每个阶段完成一个更小一点的任务。其中的 **MemberPhase 阶段**，会把类的成员都建立符号，但 MemberPhase 还会做一件有趣的事情，就是**生成缺省的构造函数**。

为什么说这个细节很有趣呢？因为这是你第一次遇到在语义分析的过程中，还要对 AST 做修改。下面我们看看这个过程。

首先，你需要重新回顾一下缺省构造函数的意思。

在编写 Java 程序时，你可以不用写构造函数。对于下面这个 MyClass5 类，我们没有写构造函数，也能正常地实例化：

复制代码

```
1 public class MyClass5{
2 }
```

但在语义分析阶段，实际上编译器会修改 AST，插入一个缺省构造函数（相当于下面的代码）。缺省的构造函数不带参数，并且调用父类的一个不带参数构造方法（对于 MyClass5 类来说，父类是 java.lang.Object 类，“super()”引用的就是 Object 类的不带参数的构造方法）。

```java
public class MyClass3{
    public MyClass3(){
        super();
    }
}
```

复制代码

对应的 AST 如下，其中 **JCMethodDecl** 这棵子树，就是语义分析程序插入的。

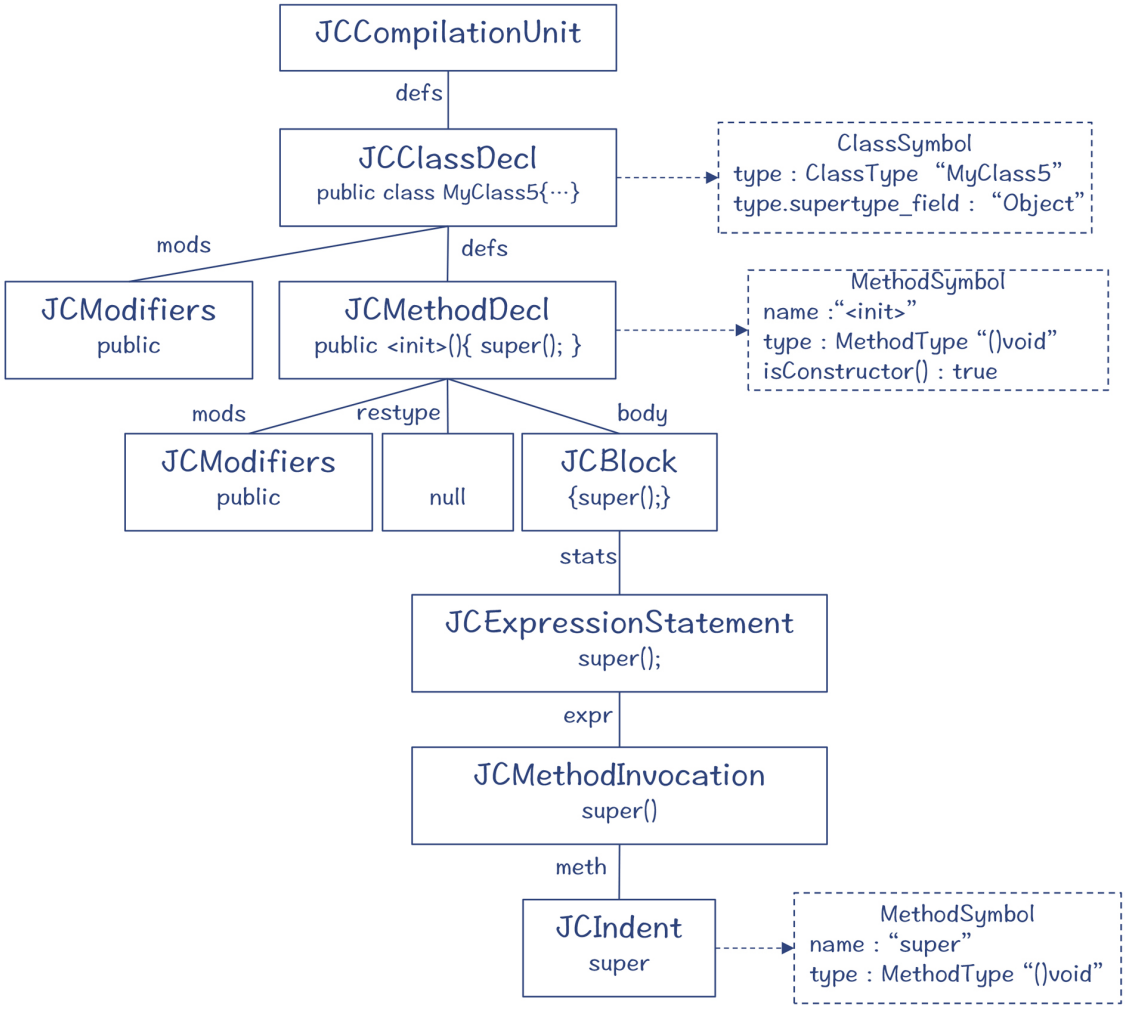

图 10：生成缺省构造函数之后的 AST，以及关联的 Symbol

新插入的构造方法是以 JCMethodDecl 为根节点的一棵子树。对于这个 JCMethodDecl 节点，在属性标注做完以后，形成了下面的属性。

名称：`<init>`。

类型：()void，也就是没有参数，返回值为 void。

符号：生成了一个方法型的符号（sym 属性），它的名称是<init>，如果调用 sym.isConstructor() 方法，返回 true，也就是说，这个符号是一个构造方法。

在这个缺省构造方法里，调用了“super();”这样一个语句，让父类有机会去做初始化工作，进而也让父类的父类有机会去做初始化工作，依次类推。

“super()”语句的叶子节点是一个 JCIndent 节点，也就是标识符。这个标识符的名称是”super “，而符号（sym 属性），则通过变量引用消解，指向了 Object 类的构造方法。

最后，我们声明 MyClass5 类的时候，也并没有声明它继承自 Object。这个信息也是自动推断出来的，并且会在类节点（JCClassDecl）的 type 属性中标注清楚。在图中你可以看到，type.supertype_field 指向了 Object 这个类型。

除了在自动生成的缺省构造函数里会调用 super()，你还知道，当我们手写一个构造函数的时候，也可以在第一句里调用父类的一个构造方法（并且必须是在第一句）。

复制代码

```
public class MyClass4 extends MyClass3{
    public MyClass4(int a){
        super(a);   //这句可以省略，编译器可以自动生成
        ...
    }
}
```

如果你不显式地调用 super()，编译器也会自动加入这样的一个调用，并生成相应的 AST。这个时候，父类和子类的构造方法的参数也必须一致。也就是说，如果子类的构造方法的签名是（int, String），那么父类也必须具备相同签名的一个构造方法，否则没有办法自动生成对父类构造方法的调用语句，编译器就会报错。**我相信你很可能在编程时遇到过这种编译信息，不过现在你应该就能清晰地了解，为什么编译器会报这些类型的编译错误了。**

总体来说，Java 的编译器会根据需要加入一些 AST 节点，实现一些缺省的功能。其中包括缺省的构造方法、对父类构造方法的缺省调用，以及缺省的父类（Object）。

更多课程推荐

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇　09 | Java编译器（一）：手写的编译器有什么优势?

精选留言

写留言

由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。